Journal of Agricultural Machinery
Vol. 8, No. 1, Spring - Summer 2018, p. 137-148

نشریه ماشین‌های کشاورزی
جلد 8، شماره 1، نیمسال اول 1397، ص 148-137

تخمین کربن آلی خاک با استفاده از مدل‌های شبکه عصبی مصنوعی و رگرسیون خطی چندگانه بر اساس پردازش تصاویر رنگی

پریسا عطائیان[1]- پرویز احمدی مقدم[2]*- ابراهیم سپهر[3]

تاریخ دریافت: 1395/07/10
تاریخ پذیرش: 1395/12/16

چکیده

کربن آلی خاک منبع عظیمی از مواد مغذی برای گیاه بوده و به‌عنوان عاملی فعال در گسترش ساختمان خاک، نقش مهمی در بهبود حاصل‌خیزی خاک‌های کشاورزی دارد. هدف اصلی از این پژوهش، تخمین میزان کربن آلی خاک در زمین‌های کشاورزی با استفاده از یک روش ساده، سریع و کم هزینه می‌باشد. 80 نمونه خاک از مزارع کشاورزی شمال آذربایجان غربی تا جنوب استان به‌صورت انتخابی جمع‌آوری شد و پس از تعیین مقدار کربن آلی نمونه‌ها در آزمایشگاه، نمونه‌ها در شرایط کنترل شده مورد تصویربرداری قرار گرفتند. تصاویر رنگی در چندین فضای رنگی مختلف تحلیل شدند و در هر فضای رنگی، مدل‌های شبکه عصبی و رگرسیون چندگانه برای برآورد میزان کربن آلی خاک توسعه یافت. نتایج مدل‌سازی خطی نشان داد که بالاترین ضریب همبستگی در فضاهای رنگی LAB و LUV به‌ترتیب 0/91 و 0/92 برای مدل‌های استخراج شده از مؤلفه‌های این فضاها و کربن آلی خاک به‌دست آمد. نتایج حاصل از طبقه‌بندی به‌وسیله شبکه عصبی نشان داد که ضریب همبستگی در فضای RGB بالاترین مقدار را داشته و برابر با 0/94 بوده است. نتایج نشان داد که در تمامی فضاها مدل‌سازی شبکه عصبی دقت مدل را افزایش داده است.

واژه‌های کلیدی: دوربین دیجیتال، شبکه عصبی، کربن آلی خاک، کشاورزی دقیق

مقدمه

نقشه‌های دقیق کربن خاک حاوی اطلاعات ضروری برای انجام عملیات بی‌خطر روی مناطق خاص بوده و برای ارزیابی کیفیت خاک مهم است. برای مثال، غلظت کربن آلی در سطح خاک، برای تعیین میزان نیاز یک مکان خاص به بعضی منابع مورد نیاز برای تولید محصول، از جمله نیتروژن و علف‌کش‌ها مورد نیاز است (Haung *et al.*, 2007; Blackmer and White, 1998).

تعیین سریع و دقیق توزیع فضایی کربن آلی خاک در مدیریت کشاورزی مطلوب است. روش‌های معمول برای تعیین کربن آلی خاک اغلب پر هزینه و زمان‌بر بوده و در تعداد بسیار زیاد قابل تکرار نیستند. ضمن اینکه این روش‌ها مقدار زیادی مواد شیمیایی مصرف می‌کنند و گاهی اوقات در نتیجه خطای فرد آزمایش‌کننده، دقت پایینی دارند (McCauley *et al.*, 1993). روش طیف‌سنجی بازتابی به‌ویژه برای خاک، امکان بررسی خواص متفاوت مربوط به رطوبت و مواد آلی را فراهم کرده است. برای ترسیم نقشه کربن خاک روش‌های سنجش از راه دور دارای یک مزیت آشکار- ماهیت سه‌بعدی تصاویر هستند اما ابزار مناسبی برای توضیح مورد نیاز است (Viscarra *et al.*, 2008).

کاربرد رنگ خاک برای شناسایی و تعیین کیفیت ترکیبات خاک سابقه طولانی دارد. رنگ خاک بستگی به نوع ترکیبات خاک دارد و این مشخصه به‌راحتی در دسترس بوده و در طول زمان به نسبت پایدار است (Schwertmann, 1993). رنگ خاک یک متغیر پیوسته است که در هر سه بعد طول و عرض و عمق زمین تغییر می‌کند. تغییر عمودی در رنگ خاک برای تشخیص سطوح مختلف در یک پروفایل، اندازه‌گیری غیرمستقیم از خصوصیات مهم خاک، شامل زهکشی، تهویه، مقدار ماده آلی و حاصلخیزی کلی را فراهم می‌سازد (Viscarra *et al.*, 2006).

اجزای مختلف خاک در گستره مرئی طیف‌های الکترومغناطیسی بین طول‌موج‌های 400 و 700 نانومتر، واکنش طیفی نشان می‌دهند و از آنجا که خاک‌های غنی از کربن آلی اغلب توسط ظاهر تیره‌شان

1 و 2- به‌ترتیب دانشجوی کارشناسی ارشد و دانشیار، گروه مکانیک بیوسیستم، دانشگاه ارومیه، ارومیه
3- دانشیار، گروه علوم خاک، دانشگاه ارومیه، ارومیه
(*- نویسنده مسئول: (Email: p.ahmadi@urmia.ac.ir
DOI: 10.22067/jam.v8i1.59228

قابل شناسایی‌اند، بیشتر تحقیقات به بازتاب در محدوده باندهای مرئی برای تعیین و ترسیم تغییرپذیری کربن توجه دارد (Viscarra *et al.*, 2008). تحلیل فضایی رنگ سطح خاک به‌طور فزاینده‌ای موضوع تحقیقات سنجش از راه دور بسیاری بوده است، چنانچه وضوح تصاویر فضایی و طیفی عکس‌برداری هوایی و ماهواره‌ای پیشرفت کرده و هزینه تصاویر کاهش یافته است (Viscarra *et al.*, 2006).

خاک‌شناسان برای تعیین رنگ خاک از نمودارهای رنگ خاک مانسل[1] نیز استفاده می‌کنند که نیاز به درک حسی از بازتاب رنگ و تطبیق بصری بین نمونه‌های خاک و تراشه‌های رنگ استاندارد دارد و یک سیستم مفید برای توصیفات کلی از رنگ خاک به‌شمار می‌رود (Melville and Atkinson, 1985). فضای رنگی مانسل به مجموعه‌ای از اجزای غیرپیوسته تقسیم شده که در صفحات کتابچه نمودارهای رنگ ارائه شده است. به علت ماهیت درونی نمودارهای رنگ مانسل، وابستگی ضعیف و تعداد محدود تراشه‌ها، این سیستم برای اندازه‌گیری دقیق رنگ خاک کمتر مناسب است.

این محدودیت‌ها موجب توسعه بیشتر تحقیقات جهت استفاده از روش‌های کامل‌تر، دقیق‌تر و سریع‌تر برای اندازه‌گیری رنگ خاک شد. روش‌های سریع مانند دوربین دیجیتال (Levin *et al.*, 2005; Viscarra *et al.*, 2008)، رنگ‌سنج‌ها (Konen *et al.*, 2003) و طیف‌سنج‌ها (Sudduth and Hummel, 1993; Shonk *et al.*, 1991; Zornoza *et al.*, 2008; Haung *et al.*, 2007; McDowell *et al.*, 2012) امکان توصیف بیشتر خصوصیات فیزیکی رنگ خاک را فراهم کرده‌اند.

در سال 1991، Shonk و همکاران یک حسگر در حال حرکت را توسعه دادند که از بازتاب نور در ناحیه 660 نانومتر برای به دست آوردن همبستگی با مواد آلی خاک استفاده می‌کرد. حس‌گر طراحی شده قابلیت اندازه‌گیری ماده آلی خاک را از 1٪ تا 6٪ داشت. در سال 1993، Sudduth and Hummel از یک حس‌گر مادون قرمز طیف کامل که بر روی اتصال سه نقطه تراکتور سوار شده بود، استفاده کردند و داده‌ها را در 26 طول موج بین 1640 و 2640 نانومتر برای پیش‌بینی مواد آلی خاک محاسبه کردند. آن‌ها ضریب تبیین 0/89 را بین بازتاب و کربن آلی خاک به‌دست آوردند.

شماری از تحقیقات استفاده از دوربین دیجیتال را برای اندازه‌گیری سریع بازتاب خاک پیشنهاد دادند. برای مثال، Viscarra و همکاران (2008) کاربرد دوربین دیجیتال را نسبت به طیف‌سنج مادون قرمزموج کوتاه مرئی برای پیش‌بینی کربن آلی خاک مقایسه کردند و به این نتیجه رسیدند که پیش‌بینی کربن آلی توسط مدل‌های ساده رنگی به همان دقت (RMSE=0.34-0.36) و حتی بهتر از پیش‌بینی‌های طیف‌سنجی (RMSE=0.36-0.54) است. Levin و همکاران (2005) از یک دوربین دیجیتال برای اندازه‌گیری درصد آهن و ذرات ریز خاک استفاده کردند و ارتباط زیادی با نتایج طیف‌سنجی به‌دست آوردند. آن‌ها ضریب تبیین 0/89 را برای مقدار آهن با ویژگی‌های استخراج شده از تصاویر گزارش کردند.

پردازش تصویر دیجیتال، روشی غیرمخرب است که با به‌کارگیری تجهیزات موجود برای جمع‌آوری تصویر مانند دوربین، کامپیوتر، اسکنر و برنامه‌های تجزیه و تحلیل تصاویر می‌تواند تصاویر را ضبط و پردازش نموده و به تجزیه و تحلیل اطلاعات مستخرج از تصاویر بپردازد (Algave *et al.*, 2012). بررسی امکان استفاده از تکنولوژی پردازش تصویر در کشاورزی در زمینه‌های مختلفی چون نظارت بر رشد مطلوب محصولات، تخمین زمان رسیدگی محصول، ماشین‌های وجین و آفت‌کش‌ها از موضوعات مورد علاقه محققان در سال‌های اخیر بوده است (Payman *et al.*, 2014).

روش‌های تحلیلی معمول برای بسیاری از خصوصیات خاک وقت‌گیر و اغلب موجب به‌کار بردن بسیاری از مواد شیمیایی است (Kamali *et al.*, 2014).

به‌دلیل اینکه در این تحقیق مدل‌سازی کربن آلی خاک بر اساس مؤلفه‌های رنگ در فضاهای رنگی مختلف صورت‌گرفته است، معرفی مختصر مهمترین فضاهای رنگی که در تحقیقات کشاورزی بیشترین کاربرد را دارند ضروری به‌نظر می‌رسد. لذا در ادامه خلاصه‌ای از این فضاها آورده شده است.

رنگ یک پدیده سه‌بعدی دیداری- حسی است. از آنجا که رنگ در مدل‌های فضای رنگی نمایش داده می‌شود، به‌موجب آن رنگ‌های اصلی توسط نقاط در این فضاها مشخص می‌شوند. بیش از یک راه برای اندازه‌گیری رنگ‌های مختلف وجود دارد. در این تحقیق تنها به مدل‌هایی که برای تشخیص رنگ کمک می‌کنند و پروفایل طیفی رنگ‌ها را به واحدهای اصلی تشخیص رنگ ارتباط می‌دهند، همچون سیستم‌های RGB، HSI، LAB و LUV پرداخته می‌شود.

رنگ در سیستم RGB با ترکیب افزایشی یا کاهشی از طیف‌های سه رنگ اصلی قرمز سبز و آبی ایجاد می‌شود. این تناظر تک‌رنگ محرک‌های اصلی به‌ترتیب در طول‌موج‌های 700، 546 و 436 نانومتر رخ می‌دهد. در یک سیستم دیجیتال 8 بیتی رنگ توسط مقادیر عددی R، G و B محدود می‌شود که در محدوده صفر (سیاه) تا 255 (سفید) قرار دارند (Fortneer and Mayer, 1997).

سیستم HSI اطلاعات رنگی یک عکس را از اطلاعات شدت رنگ آن جدا می‌کند. Hue رنگ‌های اصلی را معرفی می‌کند و توسط طول موج غالب در توزیع طیفی طول‌موج‌های نور تعیین می‌شود. Saturation مقدار خلوص رنگ است و مقدار نور سفید ترکیب‌شده با رنگ را نشان می‌دهد. محدوده مقدار رنگ از صفر تا 360 درجه است. برای مثال آبی 240 درجه، زرد 60 درجه، سبز 120 درجه و قرمز جوهری 300 درجه است. مؤلفه اشباع فاصله شعاعی از مرکز استوانه

1- Munsell color charts

را نشان می‌دهد که اندازه برداری است کـه رأس آن بـر روی محـور شدت است و انتهای آن بر روی رنگ مورد نظر در روی صفحه قـرار دارد و مؤلفه شدت رنگ ارتفاع در جهت محوری اسـت (Gonzalez and Woods, 2002; Cheng *et al.*, 2001).

پـارامتر *L در سیسـتم LAB و LUV، تـابع طـولی متریـک نشان‌دهنده روشنی که بین صفر (سـیاه) تـا 100 (سـفید) قـرار دارد، است. مختصات رنگـی *a، *b و *u و *v بـه‌ترتیـب نشـان‌دهنـده مقیاس‌های مخالف قرمز- سـبز (a+ و u+ قرمـز و a- و u- سـبز) و مقیاس‌های مخالف آبی- زرد (b+ و v+ زرد و b- و v- آبی) هسـتند (CIE, 1978). مقادیر فضاهای رنگی LAB و LUV توسط نرم‌افزار متلب محاسبه شد.

هدف از انجام این تحقیق، دستیابی به روش‌های ساده و با دقت مناسب برای تخمین کربن آلی خاک می‌باشد. مزایای کاربرد دوربین دیجیتال در مقایسه با سایر روش‌های معمول تعیین کربن آلی خاک، شامل نمونه‌برداری ساده از خاک الک شده، عدم نیاز به کاربرد مـواد شیمیایی و سمی و در نتیجه غیرمخرب بودن آن برای طبیعت است و سریع، ارزان و با دقت بالا انجام می‌گیرد.

مواد و روش‌ها

آماده‌سازی نمونه‌ها

در این تحقیق 80 نمونه خاک از عمق صفر تا 10 سـانتی‌متـری مزارع مختلف استان آذربایجان غربی جمع‌آوری شد (شکل 1). بافت خاک در 90 درصد از نمونه‌ها لوم رسی و لومی بود. مقدار pH خـاک بین 7/1 تا 7/9 و مقدار آهن بین 475 تا 790 میلی‌گرم بر کیلـوگرم متغیر بود. پس از تهیه نمونه‌ها و انتقال آن‌ها به آزمایشگاه مکانیـک خاک دانشکده کشاورزی در دانشگاه ارومیه، نمونه‌ها بـه مـدت یـک هفته در معرض هوا قرار گرفتند تا کاملاً خشک شوند. سپس نمونه‌ها از الک 0/4 میلی‌متری عبـور داده شـدند تـا مـواد اضـافی همچـون تکه‌های چوب و خرده کاه از آن‌ها جدا شود. مقدار کربن آلی نمونه‌ها با استفاده از اکسیداسیون پتاسیم دی‌کرومات بر اساس روش احتـراق مرطوب و الکلی و بلک[1] تعیین شد (Walkely and Black, 1934). برای آماده‌سازی نمونه‌ها جهت تهیه تصاویر، از پتری‌دیـش‌هـای بـا حجم 60 سانتی‌متر مکعب و قطر 10 سانتی‌متر استفاده گردید و سطح نمونه‌ها در داخل پتری‌دیش تا حد ممکن صاف شد تا تصویری یـک دست و بدون سایه تهیه شود (شکل 2 الف).

برای تأمین یکنواختی نـور در هنگـام تصـویربرداری، از محفظـه تصویربرداری مجهز به لامپ هالوژن در چهار طرف محفظه اسـتفاده گردید. زاویه قرارگیری لامپ‌های هالوژن برای کاهش بازتاب مستقیم نور بر روی نمونه‌ها، 45 درجه تنظیم شد. برای تهیه تصاویر از یـک دوربین دیجیتال سایبرشات سونی مدل HX-9V با وضـوح 16 مگـا پیکسل استفاده گردید. دوربین در فاصله 0/5 متری در بالای نمونـه داخل محفظه تصویربرداری نصب گردید. از یک رنگ‌سنج هانتر برای کالیبراسیون دوربین در این مطالعه استفاده شد. 12 کـارت رنگـی بـا مقادیر مختلف پارامترهای L^*، *a و *b برای استانداردسازی داده‌های به‌دست آمده از دوربین دیجیتال به‌کار رفت. مقدار واقعی رنگ بـرای هر کارت در محفظه تصویربرداری توسط رنگ‌سنج و دوربین تعیـین گردید. همبستگی بین پارامترهای L^*، *a و *b بـرای رنـگ‌سـنج و دوربین به‌ترتیب 0/99، 0/97 و 0/98 به‌دست آمد.

تحلیل داده‌ها

تحلیل تصاویر دیجیتال

تصاویر تهیه شده توسط دوربین، در اندازه 4608×3456 پیکسـل در فضای رنگی RGB و با فرمت JPEG ذخیره گردید. برای کاهش مدت زمان و بار محاسباتی مورد نیاز برای پـردازش تصـاویر، انـدازه تمامی تصاویر قبـل از پـردازش بـا اسـتفاده از نـرم‌افـزار متلـب بـه 1024 ×1024 پیکسل کاهش یافت (شکل 2 ب).

پس از استخراج مؤلفه‌های R، G و B، با استفاده از روابط موجود بین فضاهای مختلف رنگی، محاسبه مؤلفه‌های اصـلی در فضـاهای رنگی HSI و Lab امکان‌پذیرخواهد بود.

خصوصیات استخراج شده از تصاویر رنگی که برای مـدل‌سـازی کربن آلی خاک به‌کار رفت، شـامل مؤلفـه‌هـای رنگـی در فضـاهای مختلف بود. بنابراین برای تحلیـل و مـدل‌سـازی هـر نمونـه، مقـدار میانگین مؤلفه‌های رنگی در فضاهای مختلف به‌کار گرفته شد.

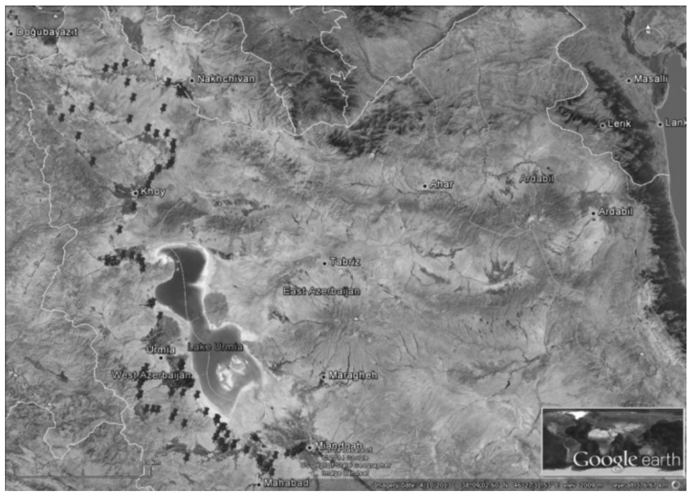
توسعه معادلات و مدل‌سازی کربن آلی خاک

داده‌ها به‌صورت تصادفی به دو گروه داده‌های کالیبراسیون (70% داده‌ها) و داده‌های اعتبارسنجی (30٪ داده‌ها) برای تسـت و ارزیـابی مدل‌ها تقسیم شد. چهار فضای رنگـی شـامل RGB، HSI، LAB و LUV برای تعیین رابطه بین رنگ و کربن آلی خـاک مـورد مطالعـه قرار گرفت. سپس مدل‌های خطی برای مؤلفه‌های اصلی رنگ در این فضا توسط مقدار کربن آلی خاک به‌دست آمده در آزمایشـگاه توسـعه یافت (جدول 1). در انتها بر اساس ارزیابی مدل‌های ایجاد شده برای داده‌های کالیبراسیون و اعتبارسنجی، سه شاخص ضریب تبیین (R^2)، خطای میانگین مربعات (MSE) و حداقل دقت پـیش‌بینـی (MPA) محاسبه گردید.

برای مدل‌سازی کربن آلی خاک توسط شبکه عصبی نیز، داده‌هـا به سه دسته آموزش، تست و اعتبارسنجی تقسیم شدند. در این مرحله، 51 داده برای آموزش شـبکه، 14 داده بـرای تسـت و 12 داده بـرای

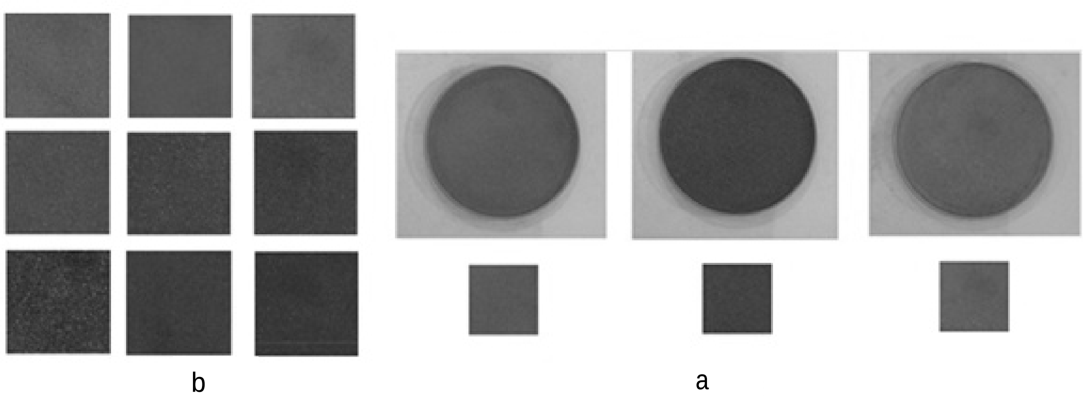
1- Walkley and Black

اعتبارسنجی شبکه به‌کار رفت. مقدار کربن آلی خاک، خروجی شبکه عصبی بود که بعد از آموزش با استفاده از مقادیر مؤلفه‌های رنگی هر قسمت برآورد شد. به‌منظور ارزیابی صحت شبکه، مقادیر برآورد شده و مقادیر واقعی هر نمونه در یک نمودار رسم شدند و ضریب همبستگی بین داده‌های واقعی و داده‌های تخمین زده شده مورد بررسی قرار گرفت. شبکه عصبی به این صورت عمل می‌کند که در مرحله آموزش، روابط منطقی ریاضی که بین متغیرهای ورودی (در این تحقیق مؤلفه‌های اصلی رنگ استخراج شده از تصاویر تهیه شده از نمونه‌های خاک است) و متغیر خروجی (درصد کربن آلی خاک) وجود دارد را پیدا کرده و به‌عنوان یک مدل شبکه برای تخمین داده‌هایی که در مرحله آموزش استفاده نشده است، استفاده می‌گردد و به این صورت مقدار خروجی که همان درصد کربن آلی خاک است پیش‌بینی می‌گردد.



شکل 1- گستره نمونه‌برداری مورد استفاده در آزمایش‌ها، استان آذربایجان غربی

Fig. 1. Sampling horizon of West Azerbaijan, Iran used in the experiments



شکل 2- (الف) تصاویر تهیه شده از نمونه‌های خشک در داخل پتری‌دیش و تصویر مرکز 1024×1024 پیکسل مورد استفاده در تحلیل عکس‌ها (ب) تغییرات رنگ در نمونه‌های مختلف خاک

Fig. 2. a) Dry soil in petri dishes and the 1024×1024 pixels regions of interest used in analysis and b) Example of color changes in different soil samples

در روش مدل‌سازی خطی نیز تقریباً با روش مشابه، مدل‌سازی صورت می‌گیرد. با این تفاوت که در این روش، مدل‌ها را خود فرد پیشنهاد می‌کند و فقط توسط نرم‌افزار ضرایب ثابت مدل بهینه می‌گردد تا مقدار خطای مدل کمترین مقدار باشد. همانطور که در بخش نتایج مشاهده می‌شود، مدل‌سازی خطی، توابعی از متغیرهای ورودی هستند که مقدار کربن آلی را تخمین می‌زند و توان همه این

ضرایب یک می‌باشد.

نتایج و بحث

نتایج بررسی آزمایشگاهی کربن آلی نمونه‌ها در جدول 1 نشان داد که میانگین کربن آلی خاک‌های زراعی منطقه آذربایجان غربی برابر 1/28% است که نشان‌دهنده فقر کربن آلی در این ناحیه است.

بررسی همبستگی کربن آلی خاک با مؤلفه‌های اصلی رنگ در فضاهای مختلف

در این بخش از تحقیق به ارائه نتایج حاصل از بررسی همبستگی بین مؤلفه اصلی رنگ در فضای RGB، HSI و Lab با مقدار کربن آلی خاک پرداخته شده و بالاترین همبستگی برای هر مؤلفه در فضاهای مختلف محاسبه شده است. نتایج این مطالعه در جدول 1 نشان داده شده است. بالاترین همبستگی بین کربن آلی خاک و مؤلفه‌های اصلی رنگی برای مؤلفه رنگ قرمز در فضای رنگی RGB به‌دست آمده است. همبستگی R در مدل RGB رابطه قوی تک پارامتری با کربن آلی خاک را با ضریب تبیین 0/83 نشان داد.

جدول 1- نتایج آماری مؤلفه‌های رنگ خاک اندازه‌گیری شده در فضاهای رنگی مختلف و ضریب همبستگی

Table 1- Statistics of color components from different color spaces and their correlation coefficient

مؤلفه فضای رنگی **Color space parameter**	میانگین Mean	میانه Median	انحراف استاندارد Standard deviation	محدوده Range	ضریب همبستگی Correlation coefficient
R	85.4852	90.667	14.423	49.667-106.667	0.83
G	81.0783	85.334	13.8145	45.334-100.667	0.8
B	78.035	81.334	12.8453	43-98.667	0.77
H	15.4434	23.4132	30.7066	-83.766- 77.4867	0.23
S	0.0482	0.0476	0.022	0.0073- 0.13885	0.12
I	81.5328	86.1117	13.5274	46.0003- 101.445	0.82
L	62.9518	64.852	4.74	49.4704- 69.0976	0.82
a*	2.4734	2.7	2.3285	-15.1- 7.55	0.19
b*	1.4878	1.92	2.1042	-5.94- 8.62	0.25
u*	8.5	8.38	3.4627	0- 17.81	0.24
v*	7.95	8.48	6.6195	0- 47.25	0.21

به دلیل این که مؤلفه رنگ قرمز حاوی اطلاعات مرکب روی هر دو بعد روشنی و رنگ است، بنابراین اندازه‌گیری‌ها بر روی وضعیت نور وابستگی زیادی به تغییرات میزان روشنایی خواهد داشت. در بین سه مؤلفه اصلی رنگ، با تیره‌تر شدن خاک، مؤلفه رنگ قرمز نسبت به دو مؤلفه دیگر تأثیر بیشتری را می‌پذیرد و از آنجا که کربن آلی موجود در خاک باعث تیره (قهوه‌ای) شدن رنگ خاک می‌گردد، بنابراین انتظار می‌رود که مؤلفه رنگ قرمز همبستگی بیشتری با تغییرات کربن آلی خاک داشته باشد. نتایج همچنین نشان داد که کربن آلی ارتباط خوبی با پارامترهای روشنایی I و L به‌ترتیب در فضاهای رنگی HSI و Lab داشته و همچنین ارتباط ضعیفی با سایر پارامترهای این فضاها دارد. سایر مؤلفه‌های اصلی این دو فضا، به‌علت ماهیت ساختارشان نمی‌توانند ارتباط مناسبی با کربن آلی خاک برقرار کنند.

مؤلفه H در فضای رنگی HSI زاویه رنگ غالب را نشان می‌دهد و تغییرات در مؤلفه‌های *a و *b از فضای رنگی LAB تغییرات رنگ را بدون تغییر در روشنایی و اشباع نشان می‌دهد. نتایج نشان می‌دهد که تغییرات کربن آلی خاک بیشتر در نتیجه تغییر در مؤلفه روشنایی رنگ است

مؤلفه‌های اصلی فضای رنگی RGB بر اساس تغییرات مقدار و روشنایی رنگ تغییر می‌کنند و به همین علت، مؤلفه‌های R و G و گاهی اوقات مؤلفه B با کربن آلی خاک همبستگی دارند. اما در دیگر فضاهای رنگی مؤلفه‌های رنگ می‌توانند علی‌رغم شدت روشنایی نور تغییر کنند. ویسکارا و همکاران (2008) با استفاده از داده‌های استخراج‌شده از تصاویر دیجیتال، بالاترین ضریب همبستگی بین مؤلفه‌های فضای رنگی را در مقابل کربن، برای مؤلفه R در فضاهای رنگی RGB با مقدار ضریب تبیین 0/85 به‌دست آوردند.

توسعه مدل‌های خطی چند متغیره کربن آلی در فضاهای رنگی

در این تحقیق، مدل‌سازی خطی چند متغیره در تمام فضاهای رنگی بر اساس مؤلفه‌های رنگی تصاویر دیجیتال در فضای RGB به‌دست آمد (جدول 3). برای تعیین بهترین مدل، مقادیر R^2 و MSE مورد مقایسه قرار گرفتند و در مواردی که این مقادیر برای مدل‌های مختلف با هم برابر بودند، مقدار MPA مورد استفاده قرار می‌گرفت.

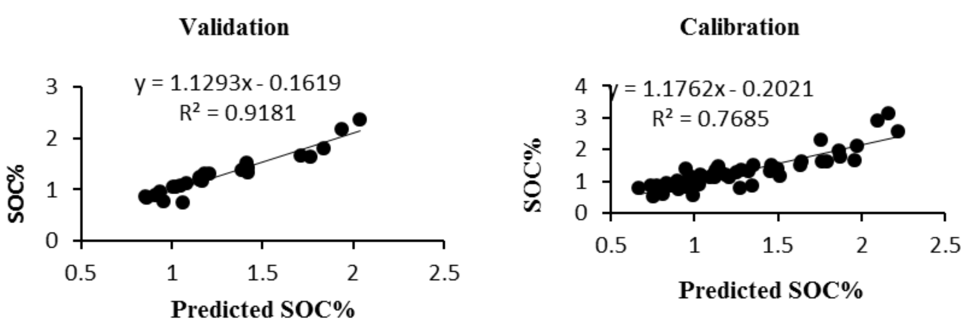
بر اساس جـدول 3 و شـکل 4، $R^2=0.92$ بـرای بهتـرین مـدل اعتبارسنجی در فضای رنگی RGB نشان می‌دهد کـه رنـگ خـاک همبستگی بالایی با میزان کربن آلی خاک دارد. همچنـین بـالاترین همبستگی زمانی به‌دست می‌آید که مؤلفه‌های R و G با هم ترکیـب شوند و مؤلفه B حـذف گـردد (شـکل 4). یـک توضـیح بـرای ایـن همبستگی بالا می‌تواند حساسیت زیاد مؤلفه B به شدت روشـنایی و زاویه تابش نور باشد. کوچکترین تغییر در نـور، ایـن مؤلفـه را تغییـر خواهد داد. بنابراین، برای کاهش تأثیر این مؤلفه، بهتر است از مدل‌ها حذف گردد و مدل‌ها مستقل از آن ساخته شوند.

بر اساس فضای رنگـی RGB (شـکل 3)، مشـخص اسـت کـه ترکیب‌های متفاوت از این دو مؤلفه اصلی، ایجاد رنگ قهوه‌ای و زرد می‌کند. از آنجایی‌که رنگ قهوه‌ای نشانه‌ای بارز از وجود کربن آلی در خاک است، همین امر موجـب همبسـتگی بـالای ایـن دو مؤلفـه بـا تغییرات کربن آلی در خاک، در بین مدل‌های توسعه‌یافتـه اسـت. در واقع بهترین مدل استخراج شده در این فضـا نیـز از ترکیـب ایـن دو مؤلفه به‌دست آمده است.

جدول 2- مدل‌های خطی چند متغیره برای پیش‌بینی مقدار کربن آلی خاک در فضاهای رنگی مختلف

Table 2- Multivariate linear color models used to predict the soil organic carbon in different color space

متغیر Variable	مدل Model	کالیبراسیون Calibration			اعتبارسنجی Validation		
		R^2	MSE	MPA	R^2	MSE	MPA
R,G	f(x)=a+b*R+c*G	0.82	0.072	64.56	0.92	0.016	56.4
R,G,B	f(x)=a+b*R+c*G+d*B	0.8	0.085	52.87	0.91	0.019	53.99
S,I	f(x)=a+b*S+c*I	0.84	0.07	68.47	0.92	0.014	76.14
H,S,I	f(x)=a+b*H+c*S+d*I	0.84	0.074	68.38	0.92	0.014	58.17
L	f(x)=a+b*L	0.83	0.071	66.21	0.91	0.016	69.56
L,A,B	f(x)=a+b*L+c*A+d*B	0.87	0.052	69.02	0.91	0.013	74.66
L,U,V	f(x)=a+b*L+c*U+d*V	0.85	0.065	70.77	0.92	0.012	76.13



f(x)=a+b*R+c*G

شکل 3- نمودار بهترین مدل کالیبراسیون و اعتبارسنجی در فضای RGB

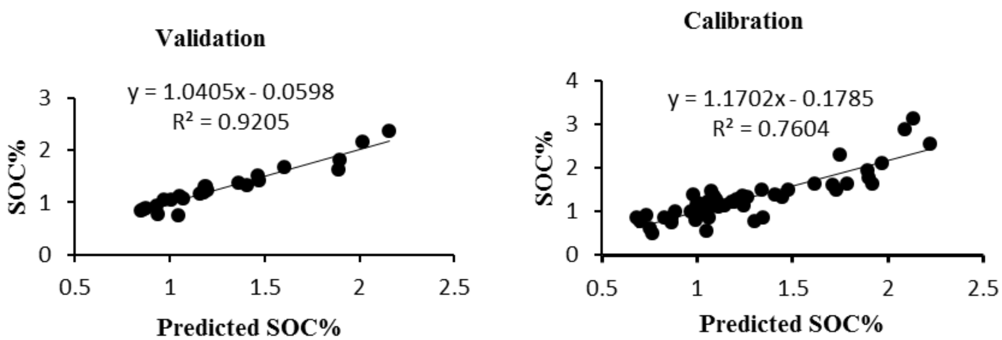
Fig. 3. The best diagram for calibration and validation models in RGB color space

نقطه ضعف اصلی سیستم RGB برای توصیف رنگ خاک، درجه بالای همبستگی بین باندهای R، G و B و تأثیر بالای شـدت نـور روی هر یک از باندها است. برای غلبه بر این مشکل، مقـادیر RGB به مدل‌های فضای رنگی مختلف دیگری تبدیل شده و نتایج حاصل از این فضاها بررسی گردید.

توسعه مدل‌های خطی چندمتغیره کربن آلی خاک در فضای HSI

بر اساس نتایج جدول 4، همبستگی مناسبی بین دو مؤلفه H و S در فضای رنگی HSI و کربن آلی وجود ندارد. مؤلفه H که زاویه رنگ غالب را نشان می‌دهد، محـدوده‌ای بـین 0 تـا 360 درجـه را شـامل می‌شود که نشان‌دهنده تغییرات طبیعی رنگ بـدون در نظـر گـرفتن روشنایی است؛ پس نمی‌تواند یک رابطه خطی با مقـادیر کـربن آلـی برقرار کند. تنها مؤلفه I این رابطه خطی را داشته که به علت تغییرات روشنایی در این فضای رنگی است. اما زمانی که همه این مؤلفه‌ها در مدل‌سازی شرکت می‌کنند، نتایج ضریب همبسـتگی بـالایی نشـان می‌دهد. می‌توان نتیجه‌گیری کرد که همپوشانی این مؤلفه‌ها بر روی هم قادر است روند تغییرات مقدار کربن آلی خاک را به‌خـوبی نشـان

دهد. تغییرات روشنایی ماهیت و خلوص رنگ را تغییر می‌دهد اما با تغییر رنگ خاک ثابت می‌ماند. شکل 5 بهترین مدل برای فضای رنگی HSI را نشان می‌دهد.



f(x)=a+b*H+c*S+d*I

شکل 4- نمودار بهترین مدل‌های کالیبراسیون و اعتبارسنجی در فضای HSI

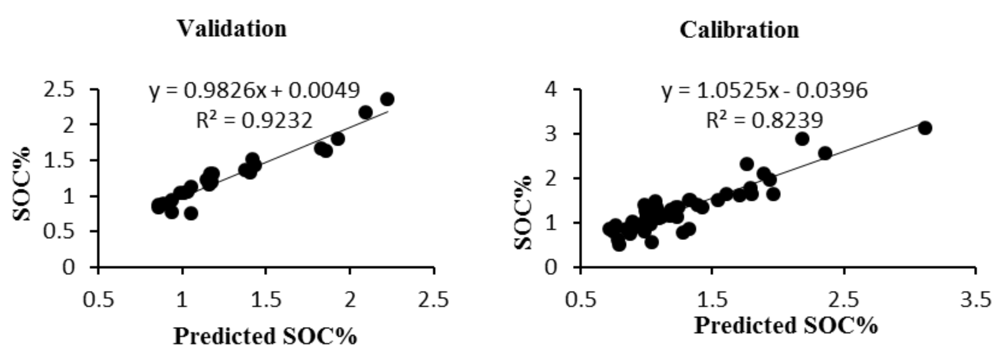
Fig. 4. The best diagram for calibration and validation models in HSI color space

توسعه مدل‌های خطی چند متغیره کربن آلی خاک در فضاهای رنگی CIELAB و CIELUV

بر طبق نتایج، کاربرد این فضاهای رنگی دقت قابل قبولی ارائه می‌دهد (جدول 4). از آنجا که اساس کار دستگاه‌های رنگ‌سنج بر مبنای فضای رنگی LAB است و این مؤلفه‌ها قابل استخراج از دستگاه‌های رنگ‌سنج است، می‌توان مدل‌های توسعه‌یافته با این فضای رنگی را برای پیش‌بینی کربن آلی خاک در این تحقیق به‌کار برد. شکل 6 و شکل 7 بهترین مدل برای فضاهای رنگی LAB و LUV را نشان می‌دهد.

نتایج حاصل از مدل‌سازی کربن آلی خاک توسط شبکه عصبی

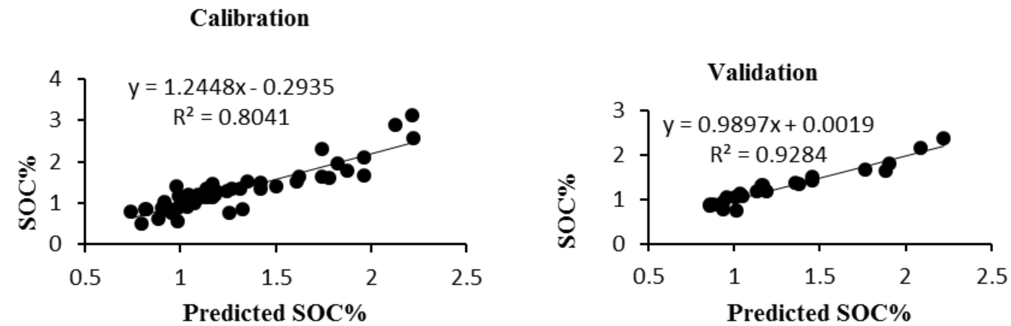
هدف اصلی از کاربرد شبکه عصبی در این تحقیق، دست‌یابی به مدل‌هایی با دقت بالاتر و همچنین اعتبارسنجی مدل‌های رگرسیون خطی و مقایسه این مدل‌سازی‌ها با یکدیگر می‌باشد. تمامی حالات تک متغیره و چند متغیره از مؤلفه‌های فضاهای رنگی مورد مطالعه، در تحلیل شبکه به‌کار رفت و نتایج در جدول 5 خلاصه شده است.



f(x)=a+b*L+c*A +d*B

شکل 5- نمودار بهترین مدل‌های کالیبراسیون و اعتبارسنجی در فضای رنگی LAB

Fig. 5. The best diagram for calibration and validation models in LAB color space

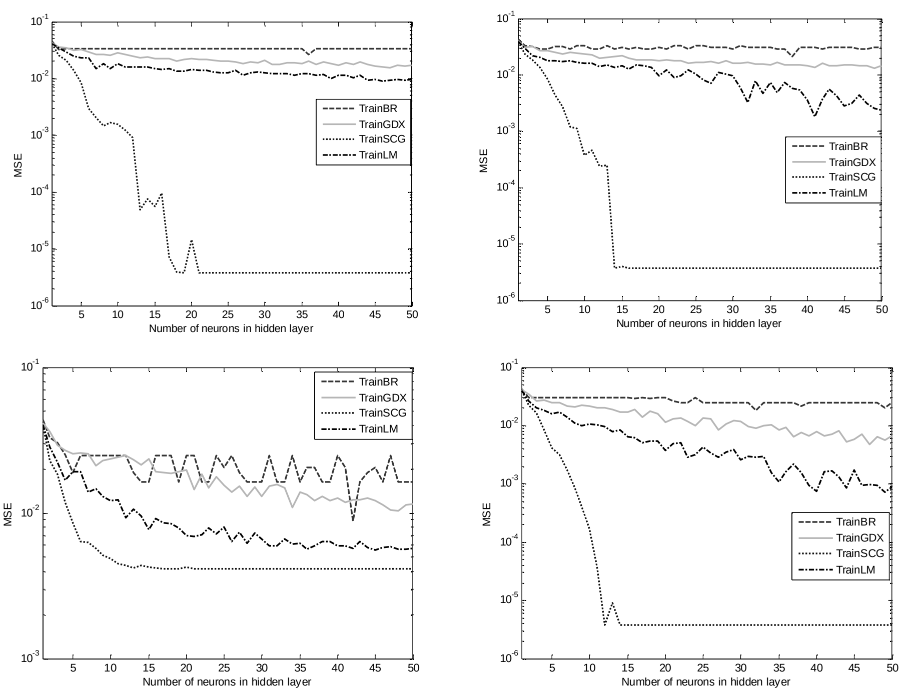


f(x)=a+b*L+c*

U+d*V

شکل 6- نمودار بهترین مدل‌های کالیبراسیون و اعتبارسنجی در فضای رنگی LUV

Fig. 6. The best diagram for calibration and validation models in LUV color space



شکل 7- نمودار MSE برای 50 نورون در لایه مخفی برای تعیین بهترین فضای رنگی در تحلیل‌ها؛ ردیف‌های بالا و پایین از راست به چپ به‌ترتیب فضاهای رنگی RGB، HSI، LAB و LUV هستند

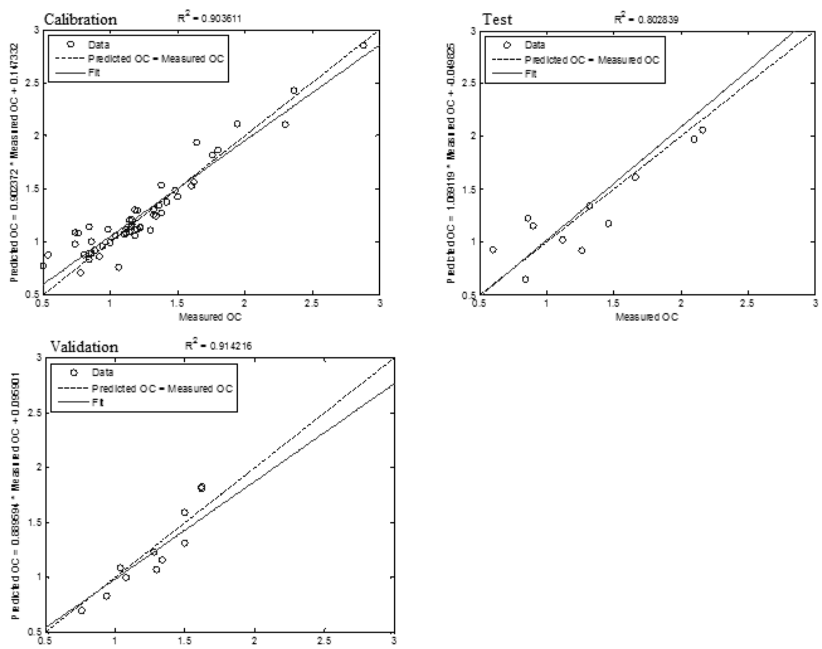
Fig. 7. MSE diagrams for 50 neurons in hidden layer to determine the best color space for analyses; top and bottom rows from left to right are RGB, HSI and LAB, LUV respectively

در ابتدا بهترین ساختار شبکه برای مدل‌سازی کربن آلی خاک در فضاهای رنگی با آموزش شبکه توسط 50 نورون و 120 تکرار به‌دست آمد. نمودار MSE برای چهار فضای رنگی با چهار تابع آموزش در شکل 9 نشان داده شده است. کمترین مقدار MSE=$7.28e^{-6}$ با 16 نورون، $3.77e^{-6}$ با 14 نورون، $4.8e^{-3}$ با 10 نورون و $3.77e^{-6}$ با 12 نورون به‌ترتیب برای فضاهای رنگی RGB، HSI، LAB و LUV بود. یک شبکه عصبی پرسپترون با یک لایه مخفی و تابع تبدیل تانژانت سیگموئید برای لایه مخفی و یک تابع خطی برای لایه خروجی مورد استفاده قرار گرفت. نتایج این بخش نشان داد که فضای رنگی LUV کمترین مقدار MSE را با 12 نورون داشت که کمتر از سه فضای رنگی دیگر است (شکل 8). بنابراین این فضای رنگی برای استخراج نمودارهای رگرسیون به‌کار رفت (شکل

9).

نتایج فضای رنگی RGB نشـان داد کـه ایـن فضـا همبسـتگی بالایی با کربن آلی خاک دارد. بر طبق نتایج مشابه مـدل رگرسـیون خطی، می‌توان نتیجه گرفت که تغییرات رنگ خاک در نتیجـه تغییـر میزان کربن آلی، تمام مؤلفه‌های فضای رنگی RGB را تحـت تـأثیر قرار می‌دهد. یک دلیل برای دقت بالا و MSE پایین در فضای رنگی RGB میزان روشنایی در وضعیت عکس‌برداری است. زیـرا تغییـرات نور محیط میزان نور بازتابیده را که توسط خاک دریافت می‌شود تحت تأثیر قرار می‌دهد. با توجه به این نکته که تغییرات نور مؤلفه‌های R، G و B را تحت تأثیر قرار می‌دهـد، لازم اسـت تصـاویر در وضـعیت نوری کنترل شده تهیه شوند تا نتایج دقیق باشد. مقدار نور بازتابیده از خاک‌های غنی از کربن آلی به‌خاطر رنگ تیره‌تر کمتر از خاک‌های با درصد پایین کربن آلی است. بنابراین می‌توان نتیجه گرفت که کربن آلی خاک مؤلفه‌های روشنایی را تحت تأثیر قرار مـی‌دهـد و خطـای کمتر در فضاهای رنگی HSI و LUV به همین علت است.

نتایج نشان می‌دهد که تأثیر کربن آلی خاک روی شدت روشنایی پیکسل‌های خاک بیشتر از مؤلفه‌های رنگ خاک اسـت. بنـابراین، در مدل‌های شامل مؤلفه‌های روشنایی مقدار کربن آلی خـاک بـا دقـت بالایی محاسبه می‌شود. شواهد نشان می‌دهد که کربن آلی خاک بـر روی نور پیکسل‌های خاک بیشتر از مؤلفه‌های رنگ تأثیر می‌گـذارد. همچنین در تصاویری که به‌طور مستقیم توسط دوربین عکاسی تهیه شده است، همه مدل‌های بر پایه پارامتر شدت روشـنایی همبسـتگی بالایی داشت و کربن آلی را با دقت بالایی تخمـین زد. از آنجـا کـه شدت روشنایی بر مقدار هر یک از پارامترهای فضـای رنگـی RGB تأثیر دارد، مدل‌های تک پارامتری نیز دقت بالایی داشتند. در حقیقت در فضای رنگی RGB روشنایی هر پیکسل خاک مجمـوع روشـنایی مؤلفه‌های R، G و B است.



شکل 8- نمودار کالیبراسیون، تست و ارزیابی برای فضای رنگی LUV به‌عنوان بهترین فضای رنگی انتخاب شده

Fig. 8. Calibration, test and validation diagrams for LUV color space as best chosen color space

نتایج مقایسه مدل‌سـازی خطـی و شـبکه‌هـای عصـبی در فضاهای رنگی مختلف

اگرچه در این مطالعه نتایج مدل‌سازی خطی و شبکه‌های عصبی نزدیک به‌هم بود، مدل‌سازی خطی قادر نبود نتایج را در تمـام مـوارد توضیح دهد. همان‌طور که در بخش مـدل‌سـازی خطـی گفتـه شـد، داده‌های ارزیابی به‌صورت تصـادفی انتخـاب شـدند. در شـبکه‌هـای عصبی از تابع دیوایدرند برای انتخاب تصـادفی داده‌هـای آمـوزش و ارزیابی استفاده شد. از این رو به دلیل متفاوت بودن داده‌های موجـود در هر دو مدل‌سازی مقایسه نتایج ارزیابی مدل‌سازی خطی و شـبکه عصبی صرفاً برای داده‌های تست، امکان‌پذیر نیست و باید شـرایطی مهیا شود تا مقایسه این دو روش مدل‌سازی برای داده‌هـای یکسـان انجام شود. پس از استخراج بهترین مدل هر یک از فضاهای رنگی در

مدل‌سازی خطی و شبکه عصبی، این مدل‌ها بر روی تمامی داده‌های مورد آزمایش اعمال شدند و ارزیابی صورت گرفته بر روی نتایج تست عیناً بر روی تمامی داده‌ها تکرار شد. در انتها ضریب همبستگی به‌دست آمده از این راه، با ضریب همبستگی مدل‌های شبکه عصبی مقایسه شد. نتایج حاصل از این بررسی در جدول 4 نشان داده شده است.

جدول 3- ضریب همبستگی به‌دست آمده از مدل‌های شبکه عصبی و خطی چندگانه در فضاهای رنگی مختلف

Table 3- Correlation coefficient obtained from neural networks and multiple linear modeling in different color spaces on all data

شماره مدل Num. of model	مدل Model	ضریب همبستگی R (Correlation coefficient) رگرسیون خطی چندگانه Multiple linear regression	شبکه عصبی Neural networks
1	R	0.89	0.94
2	G	0.87	0.92
3	B	0.85	0.93
4	R,G	0.89	0.91
5	R,B	0.88	0.92
6	G,B	0.87	0.91
7	R,G,B	0.88	0.92
8	I	0.88	0.92
9	H,I	0.88	0.9
10	S,I	0.88	0.92
11	H,S,I	0.88	0.92
12	L	0.89	0.92
13	L,a*	0.91	0.91
14	L,b*	0.88	0.9
15	L,a*,b*	0.91	0.91
16	L,u*	0.91	0.92
17	L,v*	0.9	0.92
18	L,u*,v*	0.92	0.91

همان‌طور که از جدول 4 مشخص است، نتایج مربوط به شبکه عصبی از ضریب همبستگی بسیار بهتری نسبت به مدل‌سازی خطی برخوردار است. علت این امر تفاوت ماهیت دو روش است. شبکه عصبی از توابع غیرخطی برای آموزش و مدل‌سازی استفاده می‌کند که این امر موجب ایجاد روابط بهتر میان مؤلفه‌های فضاهای رنگی و میزان کربن آلی خاک می‌شود. در نتیجه شبکه قادر خواهد بود مدل پایدارتری را در مقایسه با مدل‌سازی خطی در شرایط مختلف ارائه دهد.

بررسی نتایج حاصل از دقت شبکه بر روی تمامی داده‌ها و نتایج آن بر روی داده‌های تست این نکته را نشان می‌دهد که دقت ارزیابی مدل بر روی داده‌های تست بسیار نزدیک به دقت ارزیابی مدل بر روی تمامی داده‌ها است. در مدل‌سازی خطی ضرایب تعیین شده برای مؤلفه‌ها طوری انتخاب می‌شوند که در نهایت کمترین خطا را داشته باشند درحالی‌که در مدل‌سازی شبکه، وزن‌ها و بایاس برای داده‌ها هر بار تحت آموزش شبکه تصحیح می‌شوند تا بهترین وزن و بایاس انتخاب شود. در نتیجه در مدل‌سازی شبکه امکان افزایش دقت مدل به مراتب بیشتر از مدل‌سازی خطی است.

نتیجه‌گیری

نتایج این تحقیق نشان داد که دوربین دیجیتال می‌تواند برای استخراج ویژگی‌های مورد نیاز برای تعیین رنگ خاک و برآورد مقدار کربن آلی خاک با دقت و سرعت بالا در وضعیت آزمایشگاهی به‌کار رود. در دسترس بودن دوربین دیجیتال و امکان استفاده از آن در شرایط مختلف، کم هزینه بودن و امکان آماده‌سازی تعداد زیادی نمونه‌ها، از مزیت‌های این روش برای برآورد مقدار کربن آلی خاک است. بنابراین عکس‌برداری دیجیتال می‌تواند به‌عنوان ابزار تحلیلی برای ارزیابی معیارهای کیفی خاک مورد استفاده قرار گیرد. علاوه بر این هزینه کم ارزیابی نمونه‌ها، امکان تفکیک زمانی و مکانی بالایی را برای نظارت در مناطق بزرگ فراهم می‌کند که می‌تواند ضعف مدیریت را به‌شدت پایین بیاورد. با این‌حال، برای توسعه مدل‌های قابل‌اطمینان‌تر، تعداد بیشتر نمونه از انواع مختلف خاک و مناطق با طیف گسترده از خصوصیات خاک مورد نیاز است.

References

1. Aglave, V. A., S. B. Patil, and N. B. Sambre. 2012. Imaging technique to measure leaf area, Disease Severity and Chlorophyll Content: A Survey Paper. Journal of Computing Technologies 1 (3).
2. Barrett, L. R. 2002. Spectrophotometric color measurement in situ in well drained sandy soils. Geoderma 108 (1): 49-77.
3. Blackmer, A., and S. White. 1998. Blue arrow e-Alerts. Australian Journal of Agricultural Research 49 (3): 555-564.
4. Cheng, H. D., X. H. Jiang, Y. Sun, and J. Wang. 2001. Color image segmentation: advances and prospects. Pattern Recognition 34: 2259-2281.
5. Christy, C. D. 2008. Real-time measurement of soil attributes using on-the-go near infrared reflectance spectroscopy. Computers and Electronics in Agriculture 61 (1): 10-19.
6. DE L'ECLAIRAGE–CIE, C. I. 1978. Recommendations on uniform color spaces, color difference equations and psychometric color terms. CIE Publication (15): 9-12.
7. Fortner, B., and T. E. Meyer. 1997. Number by colors: a guide to using color to understand technical data. TELOS, Electronic Library of Science.
8. Gonzalez, R. C., and R. E. Woods. 2002. Digital image processing. Prentice hall Upper Saddle River, NJ.
9. Huang, X., S. Senthilkumar, A. Kravchenko, K. Thelen, and J. Qi. 2007. Total carbon mapping in glacial till soils using near-infrared spectroscopy, Landsat imagery and topographical information. Geoderma 141 (1): 34-42.
10. Kamali, M., S. J. Razavi, M. Sadeghi, and S. M. Shafaei. 2014. Modeling moisture absorption kinetics of barley grain using viscoelastic model and neural networks. Journal of Agricultural Machinery 5 (2): 270-280. (In Farsi).
11. Konen, M., C. Burras, and J. Sandor. 2003. Organic carbon, texture, and quantitative color measurement relationships for cultivated soils in north central Iowa. Soil Science Society of America Journal 67 (6): 1823-1830.
12. Levin, N., E. Ben-Dor, and A. Singer. 2005. A digital camera as a tool to measure colour indices and related properties of sandy soils in semi-arid environments. International Journal of Remote Sensing 26 (24): 5475-5492.
13. McCauley, J., B. Engel, C. Scudder, M. Morgan, and P. Elliott. 1993. Assessing the spatial variability of organic matter, American Society of Agricultural Engineers. Meeting (USA).
14. Melville, M., and G. Atkinson. 1985. Soil colour: its measurement and its designation in models of uniform colour space. Journal of Soil Science 36 (4): 495-512.
15. Payman, S. H., A. Bakhshipour Ziaaratgahi, and A. Jafari. 2014 Exploring the possibility of using digital image processing technique to detect diseases of rice leaf. 2014. Journal of Agricultural Machinery 6 (1): 69-79. (In Farsi).
16. Rossel, R., C. Walter, Y. Fouad, J. Stafford, and A. Werner. 2003. Assessment of two reflectance techniques for the quantification of the within-field spatial variability of soil organic carbon, Precision agriculture: Papers from the 4th European Conference on Precision Agriculture, Berlin, Germany, 15-19 June 2003. Wageningen Academic Publishers, pp. 697-703.
17. Schulze, D. G., J. L. Nagel, G. E. Van Scoyoc, T. L. Henderson, M. F. Baumgardner, and D. Stott. 1993. Significance of organic matter in determining soil colors. Soil color (soilcolor), 71-90.
18. Shonk, J., L. Gaultney, D. Schulze, and G. Van Scoyoc. 1991. Spectroscopic sensing of soil organic matter content. Transactions of the ASAE (USA).
19. Smith, A. R. 1978. Color gamut transform pairs, ACM Siggraph Computer Graphics. ACM, pp. 12-19.
20. Sudduth, K., and J. Hummel. 1993. Soil organic matter, CEC, and moisture sensing with a portable NIR spectrophotometer. Transactions of the ASAE (USA).
21. Viscarra, R., Y. Fouad and C. Walter. 2008. Using a digital camera to measure soil organic carbon and iron contents. Biosystems Engineering 100 (2): 149-159.
22. Viscarra, R., B. Minasny, P. Roudier, and A. McBratney. 2006. Colour space models for soil science. Geoderma 133 (3): 320-337.
23. Walkley, A., and I. A. Black. 1934. An examination of the Degtjareff method for determining soil organic matter, and a proposed modification of the chromic acid titration method. Soil science 37 (1): 29-38.

Journal of Agricultural Machinery
Vol. 8, No. 1, Spring - Summer 2018, p. 137-148

نشریه ماشین‌های کشاورزی
جلد 8، شماره 1، نیمسال اول 1397، ص 148-137

Estimation of Soil Organic Carbon using Artificial Neural Network and Multiple Linear Regression Models based on Color Image Processing

P. Ataeiyan[1]- P. Ahmadi Moghaddam[2*]- E. Sepehr[3]

Received: 01-10-2016
Accepted: 06-03-2017

Introduction

The color of soil depends on its composition and this feature is easily available and rather stable. Fast and accurate determination of soil organic matter distribution in the agricultural fields is required, especially in precision farming. General laboratory methods for determining the soil organic carbon are expensive, time-consuming with many repetitions, and high consumption of chemicals. Soil scientists use the Munsell soil color diagrams to define the soil color. Due to the nature of Munsell color diagrams; this system is less suitable for recognizing exact color of the soil because of weak relationship and limited number of chips. Fast methods like image processing, colorimetric and spectroscopy provide a description of most physical characteristics of the soil color. Some of the advantages of using digital cameras was used in this study, are simple sampling of screened soil, being free from chemicals and toxic materials and being fast, inexpensive and precise.

Material and Methods

In this research, 80 A-horizon (0-10 cm) soil samples were collected from various agricultural soils in west Azerbaijan, in the North West of Iran. Soil texture of these fields was loam clay and clay. The amount of organic carbon in samples was determined. The camera was installed at the distance of 0.5 m from the Petri dish on the lighting compartment. Captured images with the digital camera were saved in RGB color space. Processing operations were done by MATLAB 2012 software. The features extracted from the color images are used to model the soil organic carbon including the color features in different spaces. Four-color spaces including RGB, HSI, LAB and LUV were studied to find the relation between the color and the soil organic carbon.

Results and Discussion

The correlation of R component in the RGB model shows a strong single-parameter relation with the organic carbon as R^2=0.83. This good relationship can be due to the compound information of the red color component on both brightness and chromaticity dimension. The results also show that the organic carbon has a relatively strong correlation with the light parameters, intensity and lightness in the HSI, Lab and LUV color spaces respectively. It also has a weak correlation with other parameters, since they cannot have a proper linear correlation with organic carbon due to their structural nature. Results show that the highest correlation is obtained when the R and G components participate in modeling and the component B is omitted. One explanation of this high correlation could be the high sensitivity of component B to the intensity and the angle of light. Even a small change in light changes this component. Thus, in order to reduce the effect of this component, it is better to omit it from the models and make models independent of it. In next section, 51 data were used to train neural network, 14 data were used to test the network and 12 data for network validating. The amount of soil organic carbon was output of the neural networks that was estimated after training using the color component values of each segment. To assess the accuracy of the network, estimated values and actual values of each sample were plotted in a graph. The minimum MSE values were 7.28e-6 with 16 neurons, 3.77e-6 with 14 neurons, 4.8e-3 with 10 neurons and 3.77e-6 with 12 neurons for RGB, HSI, Lab and LUV color spaces respectively.

Conclusions

The availability of digital cameras, possibility to use it in different situations, being inexpensive and providing many samples are the advantages of this method to estimate the soil organic carbon amount. Therefore, digital photography can be used as an analytical method to evaluate the soil fertility. It also requires a low cost of sample testing, and can provide a good possibility of time and place classification for studying a vast area. However to develop more reliable models, more effort is needed, such as collecting more soil samples of different areas that include a wide range of soil features.

Keywords: Digital camera, Neural networks, Organic carbon, Precision agriculture

---

1 and 2- MSc student and Associate Professor, Department of Biosystem Engineering, Faculty of Agriculture, Urmia University, Urmia, Iran

3- Associate Professor, Department of soil science, Faculty of Agriculture, Urmia University, Urmia, Iran

(*- Corresponding Author Email: p.ahmadi@urmia.ac.ir)